

ニューラルネットワークを用いた高減衰積層ゴムの復元力特性認識と動的解析に関する検討

松田 泰治¹・藤原 祐貴²・朴 敬勳³・梶田 幸秀⁴

¹フェロー会員 九州大学大学院 教授 工学研究院 社会基盤部門

(〒819-0395 福岡県福岡市西区元岡 744)

E-mail: mazda@doc.kyushu-u.ac.jp

²学生会員 九州大学大学院 工学府 建設システム工学専攻 修士課程

(〒819-0395 福岡県福岡市西区元岡 744)

E-mail: fujiwara@doc.kyushu-u.ac.jp

³学生会員 九州大学大学院 工学府 建設システム工学専攻 博士課程

(〒819-0395 福岡県福岡市西区元岡 744)

E-mail: park@doc.kyushu-u.ac.jp

⁴正会員 九州大学大学院 准教授 工学研究院 社会基盤部門

(〒819-0395 福岡県福岡市西区元岡 744)

E-mail: kajita@doc.kyushu-u.ac.jp

本研究では関数近似能力の高いニューラルネットワークに着目し、高減衰積層ゴム(HDR)の履歴復元力特性の認識に活用できることを確認した。HDRに対して正弦波を載荷実験により入力して得られた荷重－変位関係を教師データとし、それらをニューラルネットワークに学習させた。また、学習済みのニューラルネットワークが未学習の地震動を対象とした非線形動的解析を行う際の数値演算サブルーチンとして利用可能であるかを検証した。

Key Words: nural network, AI, HDR, hysteresis loop, dynamic analysis

1. はじめに

ディープラーニングは、人間の脳神経系の仕組みを工学的に模したニューラルネットワークを多層に重ねたもの(階層型ニューラルネットワーク)により構成される。このニューラルネットワークは学習能力と自己組織化能力を有する情報処理システムであり、その特徴はあらかじめ与えられた多数の入出力データから任意の連続写像関数を自動的に作成できることにある。従って、それらの関係式の形が事前に明示されていない場合でも、簡易に近似関係を構築することができる。

一般に、新材料や新たに開発された免震・制震装置などの履歴復元力特性のモデル化は実験で得られた荷重－変位関係から、その履歴曲線の特徴をとらえた最適なモデルを数学モデルより選択し、パラメータを調整することで行われる。しかし、新材料や装置の特徴をとらえた

最適なモデルが複雑となる場合や、実挙動をうまく再現できない場合がある。一方、ニューラルネットワークは高度な学習能力を有するため、実験等で得られた荷重－変位関係を自動的に認識・記憶して数値演算サブルーチンとして非線形動的応答解析に活用できる可能性がある。

ニューラルネットワークの関数近似能力に着目し、それを用いて部材の履歴復元力特性を再現しようといくつかの研究が行われてきた。山本¹⁾は Ramberg-Osgood 型モデルの履歴曲線を対象にニューラルネットワークの認識能力が数学モデルと同程度であることを示した。吉川²⁾は積層ゴムの履歴復元力特性の認識に対してニューラルネットワークが適用し数値演算サブルーチンとしての利用可能であることを指摘している。また、矢葺ら³⁾は高減衰積層ゴムの載荷実験結果を教師データとしニューラルネットワークに学習させることで復元力特性をモデル化した。しかし、ここでは試験体から得られた荷重－変

位関係に対してのみ検討を行っている。また、ゴム層厚に対してのせん断ひずみが 100% 以内の低ひずみ領域での検討を行っているため実規模相当の検証を行えていない。そこで、本研究では高減衰積層ゴムのせん断ひずみ 50~250% の高ひずみ域を含む載荷試験から得られた荷重—変位関係を実規模スケールに拡大したものを学習させることで、ニューラルネットワークが高減衰積層ゴムの復元力特性を認識しモデル化可能かどうかを確認する。また、学習させたニューラルネットワークを数値演算サブルーチンとして使用することで非線形動的応答解析を行う手法を検討する。

2. ニューラルネットワークの構築

(1) ニューロンモデル

ニューロンモデル⁴⁾とは生物の神経細胞における情報処理の仕組みを工学的にモデル化したものである。以下では単一のニューロンモデルの信号処理組織のことをノードと呼ぶ。このノードの特徴は図-1に示すような多入力1出力の構造にある。任意のユニットに対して図-1のように隣接する n 個のノードから $x_1, x_2, \dots, x_n$ の信号が出力される。 w は隣接するユニット間の結合の強さを表すもので結合荷重と呼ばれる。図中の黒く塗られたノードはバイアスと呼ばれるもので、ノードの出力を抑制したり促進したりするパラメータ（閾値）を与える。計算上バイアスは恒等的に 1 を出力するノードとして考慮するため、閾値は他の結合荷重と同様に扱われる。信号入力の流れは、隣接する n 個のノードからの出力信号が結合荷重により増幅または減衰された後、入力信号となる。入力された n 個の入力信号の総和が内部ポテンシャル x となり、 x のフィルタのような働きを持つ活性化関数 f を通して出力信号 Y となる。本研究では、活性化関数として ReLU 関数⁵⁾、最終層にのみ恒等関数を用いた。ReLU 関数は、入力値が 0 より小さいときは 0 を、そうでないときは入力値をそのまま出力する。恒等関数は、入力値をそのまま出力値として返す。

(2) 階層型ニューラルネットワーク

多層ニューラルネットワークは、入力層、中間層、出力層からなる。一般的に、入力層、出力層は 1 層であり、中間層は複数層ある。このように層が重なった構造をしているものを階層型ニューラルネットワークと呼ぶ。本研究では、中間層が n 層の階層型ニューラルネットワークのことを、 $n+2$ 層ニューラルネットワークと呼ぶこととする。また、各層に含まれる要素の数のことをノードと呼び、1 層あたりに含まれるノードの個数をノード数と呼ぶ。本研究では、同一のネットワークにおいて中間層のノード数はすべて同数とした。また、入力層のノード




図-1 ニューロンモデル

ドのことを入力要因、出力層のノードのことを出力要因と呼ぶ。

(3) 入出力要因の選定


入出力要因はディープラーニングの結果に大きな影響を与える要素である。入力要因は対象とする数学モデルの非線形履歴挙動を特徴づけるパラメータを適切に選定する必要がある。本研究では既往の研究⁶⁾を参考にし、以下の入力要因を選択した。非線形の履歴は載荷方向が変化する際の変位や荷重の大小によりそれ以降の挙動が支配されることが知られている。したがって、まず最大経験変位、最大経験荷重、最小経験変位、最小経験荷重の 4 パラメータを選択した。また、非線形の履歴は最新折り返し点の影響を受ける場合もあるため、最新折り返し点変位および最新折り返し点荷重を加えた。剛性変化に関わる情報としては、1 ステップ前の変位増分と、1 ステップ前の荷重増分を加えた。履歴の連続性を考慮するために 1 ステップ前の変位、1 ステップ前の荷重を加え、これらに現時点の変位を加えた 11 個を入力要因とした。出力層は非線形動的解析への適用を考慮し、現時点の接線剛性とした。

・入力要因


- $X_{\max}$: 最大経験変位
- $P_{\max}$: 最大経験荷重
- $X_{\min}$: 最小経験変位
- $P_{\min}$: 最小経験荷重
- X_0 : 最新折り返し点変位
- P_0 : 最新折り返し点荷重
- X_{n+1} : 1 ステップ前の変位
- P_{n+1} : 1 ステップ前の荷重
- $X_{n+1} - X_{n+2}$: 変位増分
- $P_{n+1} - P_{n+2}$: 荷重増分
- X_n : 現時点変位

・出力要因

- K_n : 接線剛性



(a) 平面図



(b) 断面図 (単位 mm)

図-2 試験体の寸法、形状

3. 動的載荷実験

構造物の死荷重相当の鉛直荷重を考慮した動的載荷実験を行った。実験の目的は、高減衰積層ゴム試験体の復元力特性を把握し、それをもとにニューラルネットワークでの学習における教師データを作成するためである。図-2 に実験で用いた HDR 試験体の寸法・形状を示す。実験方法は高減衰積層ゴムの試験体に油圧ジャッキにより 60kN (面圧 6N/mm²) の鉛直荷重を加えて、20kN ハイブリットアクチュエータによってせん断変形あたえることで高減衰積層ゴムの試験体の荷重および変位を測定する。

道路橋支承便覧⁸⁾を参考にせん断ひずみがゴム層厚 (16mm) の 50%(8mm), 100%(16mm), 150%(24mm), 200%(32mm), 250%(40mm) を片振幅とした 0.5Hz の正弦波によりそれぞれ 5 波ずつ加振した。各振幅間は 5 秒の間隔をあけて加振した。0.002 秒間隔で計測した各ひずみ 5 波の履歴曲線を図-3 に示す。特徴としては連続的に接線剛性が変化し、高次関数で現わされる形状をしている。200, 250% の高ひずみ領域においてはハードニング現象が確認できる。




図-3 測定結果の履歴曲線




図-4 各ひずみの 1 波目の履歴曲線

既往の研究³⁾⁷⁾では、試験体から得られた荷重—変位関係を学習データとして用いていたが、その場合、振動特性が実現象とは異なるため、実挙動を想定した検証が行えていなかった。実橋梁に使用される 700mm 角のサイズの高減衰積層ゴムと仮定して今回の実験はあくまで 100mm 角の 7 分の 1 スケールの相似モデルと想定して用いたものである。そこで本研究では、より実挙動の検証に近づけるため実験結果を相似則に基づき実規模スケールへ拡大した。700mm 角の高減衰積層ゴムは 100mm 角に対してゴム層厚が 7 倍、有効面積が 49 倍となるので、実験結果の変位を 7 倍、荷重を 49 倍することで 100mm 角と同じ応力—ひずみ関係を維持し 700mm 角の高減衰積層ゴムの想定した荷重—変位関係となり、これを学習データとして用いることとした。

4. ニューラルネットワークによる学習

載荷実験により得られた高減衰積層ゴムの荷重—変位関係をニューラルネットワークに学習させることで履歴復元力特性の認識の検討を行った。既往の研究⁹⁾より単




図-5 前処理後の時刻歴接線剛性




図-6 前処理後の荷重－変位関係




図-7 時刻歴接線剛性比較（正規化後）




図-8 履歴曲線の比較

なる正弦波よりも漸増漸減正弦波を学習させた方が、非線形動的解析に有効であるということから漸増漸減正弦波を学習波として用いることとする。今回は、各ひずみの実験結果の1波目をそれぞれ取り出し、つなぎ合わせることで漸増漸減正弦波を作成した。各ひずみの1波目の履歴曲線を図-4に示す。

(1)学習データの前処理

測定した実験データに前処理を行い学習データを作成した。数学モデルを学習波として使用する場合は、解析ソフトの結果として接線剛性が荷重－変位関係と同時に取得できていたが、本研究では実験データは荷重と変位しかないため、現時点の接線剛性を現時点と1ステップ前の荷重－変位の傾きとすることで導出した。この際、変位に関してはノイズを除去した正弦波データを用いた。また、荷重に関しては履歴の折り返し点ごとに速度が反転する際に発生する摩擦の影響があるため、摩擦の影響を除去したのちに最小二乗法で近似したデータを用いた。以上のスムージング処理を事前に行い接線剛性が無限大になる状態を回避し、ばらつきを少なくすることで学習しやすいデータを作成した。前処理後の時刻歴接線剛性と履歴曲線を図-5,6に示す。

(2)ニューラルネットワークの学習

誤差逆伝搬法を学習アルゴリズムとして用い、出力層の値と教師データの値の誤差を最小化するように出力層から入力層へ向かって Adam 法⁹⁾を用いて結合荷重を修正した。学習を行うにあたって、入力要因と出力要因はすべて最大値が1、最小値が0となるように正規化したものを用いた。データ数は全部で9000個、ネットワーク構造は入力層のノード数が11、出力層のノード数が1、中間層のノード数はそれぞれ100とした。中間層の層数は試行錯誤的に求めた結果、7層が最適となった。学習回数は10万回とした。

(3)履歴復元力特性の認識結果

履歴復元力特性の認識精度を確認するために学習済みネットワークからの出力と正解である学習データとの時刻歴接線剛性比較（正規化後の値）を図-7、ニューラルネットワークからの出力をもとに作成した荷重－変位関係と正解である荷重－変位関係の比較を図-8に示す。図-7より、極値付近に僅かなずれがあるものの正解に近い値を推定できていることが確認できる。時刻歴接線剛性の正解と推定の最大誤差は約20%程度であった。また、図-8に注目すると高減衰積層ゴムの復元力特性の特徴を

とらえた履歴曲線を再現できていることが分かる。

5. 非線形動的解析への適用

1 質点系モデルを対象とし、学習済みのニューラルネットワークを数値演算サブルーチンとして使い、実地震波に対する構造物の応答推定への応用についての検討を行った。学習済みのニューラルネットワークでは、入力層に与えられた変位等の信号に対して教師信号に基づき決定された結合荷重を用いた処理が一方方向に進行し、最

最終的に出力層から現時点における接線剛性が出力される。従って、動的解析を行う際には現時点において既知の情報である入力要因から現時点接線剛性を求める数値演算サブルーチンとして本ネットワークを用いる。次ステップの応答を求める計算には線形加速度法を用いた。入力加速度は道路橋示方書¹⁰⁾が規定するレベル2地震動の内タイプIIのII種地盤(2-II-1, 2-II-2, 2-II-3の計3波、それぞれ40秒)を参照した。振幅調整を行っていない実地震波を使用すると最大応答変位がせん断ひずみ400%を超え、実挙動ではゴム支承が破断するレベルの変位が出ている




図-9 時刻歴応答変位比較 (2-II-1)




図-10 履歴曲線比較 (2-II-1)




図-11 時刻歴応答変位比較 (2-II-2)




図-12 履歴曲線比較 (2-II-2)




図-13 時刻歴応答変位比較 (2-II-3)




図-14 履歴曲線比較 (2-II-3)

ため、最大応答変位がせん断ひずみ 250%以内になるように加速度を 0.5 倍したものを使用した。構造モデルは 1 質点系で、一本柱モデルの橋脚と地盤を剛であると仮定したものとする。質点の質量は載荷実験の面圧と等しくなるように 700mm 角相当の上載圧に換算し 2940kN とした。減衰定数は 0、時間間隔は学習データと同じ 0.002 秒間隔で解析を行った。非線形動的解析の数値演算サブルーチンとしてニューラルネットワークを使用した解析結果と数学モデルを用いた解析結果との比較を行った。比較に用いた数学モデルは、高減衰積層ゴムの履歴復元力特性を考慮して提案されたバイリニア型 Double-Target モデル¹¹⁾を用いた。解析結果の時刻歴応答変位比較と履歴曲線比較を図-9-14 に示す。

図-9,11,13 よりすべての地震波において最後まで変位が発散することなく解析が行えていることが確認できる。バイリニア型 Double-Target モデルとの比較に注目すると最大応答変位においてはニューラルネットワークの方が大きな値を示している。図-10,12,14 よりすべての地震波において高減衰積層ゴムの復元力特性の特徴を持った形状の履歴曲線が再現できていることが確認できる。応答変位同様にバイリニア型 Double-Target モデルよりも荷重変位ともに大きな値を示す傾向がある。

6. まとめ

本研究では、ニューラルネットワークの関数近似能力を高減衰積層ゴムの履歴復元力特性の認識に対して活用することの有用性、及び教師データに基づき学習を行ったニューラルネットワークを非線形動的解析時の数値演算サブルーチンとして利用することの可能性について検討を行った。その結果、以下のことが明らかになった。

- (1)適切な入力要因を選定し、漸増漸減正弦波を学習させたニューラルネットワークは実規模スケールの高減衰積層ゴムの非線形履歴曲線を再現可能であることが確認された。
- (2)載荷実験により得られた復元力特性に対して適切な前処理を行うことで、ニューラルネットワークが精度の高い高減衰積層ゴムの履歴復元力特性の認識を可能であることが確認された。

(3)学習済みネットワークを用いて実地震波に対する応答解析を行った。その結果、ランダムな非線形履歴に対して低ひずみ領域から高ひずみ領域まで履歴が再現できていることが確認された。

(4)非線形動的解析において、40 秒間連続的に不安定になることなく解析が行えていることが確認された。

以上のことからニューラルネットワークの関数近似能力が高減衰積層ゴムの履歴復元力特性の認識に対して有効であり、学習済みニューラルネットワークが非線形動的解析の数値演算サブルーチンへ適用可能であるという知見が得られた。

参考文献

- 1) 山本広祐：ニューラルネットワークによる履歴挙動のモデリングと数値解析への応用，構造工学論文，Vol.38A,pp.85-94,1992.3.
- 2) 吉川和秀：ニューラルネットワークによる復元力モデルを用いた地震応答解析，日本建築学会関東支部研究報告集，pp.9-12，1992.
- 3) 矢葺亘，椋山義規，松田泰治：ニューラルネットワークによる高減衰ゴム履歴曲線の認識，構造工学論文集，Vol.43A,pp.843-848,1997.3.
- 4) 岡谷貴之：深層学習，pp.7-14，講談社，2015.4.
- 5) 斉藤康毅：ゼロから作る Deep Learning，pp.51-52，オライリージャパン，2016.9.
- 6) 松田泰治，椋山義規，入江達雄，高山智宏：ニューラルネットワークの動的非線形問題への適用に関する研究，構造工学論文集，Vol.42A,pp.635-644,1996.3.
- 7) 松田泰治：ニューラルネットワークを利用した非線形構造解析プログラムの開発，科学研究費補助金(基盤研究(B)(2)) 研究成果報告書,pp54-60,2004.9.
- 8) (社)日本道路協会：道路橋支保便覧，2018.12.
- 9) 斉藤康毅：ゼロから作る Deep Learning，pp.175-176，オライリージャパン，2016.9.
- 10) (社)日本道路協会：道路橋示方書・同解説 V 耐震設計編，2017.11.
- 11) K. H. Park, Y. Fujiwara, T. Mazda, Y. Kajita : Evaluation of mechanical properties considering hysteresis characteristic of high damping rubber bearing, Journal of Physics: Conference Series, Vol.1687, No.1, 012019, 24.11.2020.

HYSTERESIS CHARACTERISTIC RECOGNITION AND DYNAMIC ANALYSIS OF HIGH DAMPING RUBBER BEARING USING NEURAL NETWORK

Taji MAZDA, Yuki FUJIWARA, Kyeonghoon PARK and Yukihide KAJITA

In this research, we focused on neural networks with high function approximation ability and was confirmed that it could be utilized for recognition of hysteresis characteristics of high damping rubber bearing(HDR). The load displacement relation obtained by loading experiment is used as training data, and was learned by neural network. Moreover, we verify that a trained neural network can be used as a numerical operation subroutine in carrying out nonlinear dynamic analysis for untrained earthquake motion.